システムソフトウェア技術部会

活動報告

堀　敦史
システムソフトウェア技術部会 部会長（理研）
清水　正明
システムソフトウェア技術部会 副部会長（日立）

2019/2/22

- IHK/McKernel
  - 最新情報
- Process in Process (PiP)
  - 新しい並列実行環境の紹介


McKernel

Linuxカーネルの問題点

- **Linux はころころ変わる**
  - 頻繁かつ大胆に変わる
    - Linux カーネルを改変し，かつ，catch-up するのは非常に大変
  - 多様なハードウェア
    - 次々に現れるデバイスハードウェア
    - デバイスドライバの作成にはH/Wの詳細な情報が不可欠
- **Linux カーネルを改造するのは非常に大変**
  - プロダクトとしては不可能に近い
- **しかしながら，言語環境，実行環境は Linux を継承したい**
  - 環境も作るのは大変
  - Linux API/ABI との互換性をどのように実現するか？

軽量カーネルの問題点

- **軽量カーネル**
  - 必要最小限の機能のみを提供
- **利点**
  - 小さいので，改変（カスタマイズ）が容易
- **欠点**
  - 独自カーネルなため，ソフトウェアエコシステムがない（独自ABI）
    - 汎用デバイスドライバ
    - ソフトウェアツール
    - その他オープンソースソフトウェア


big
small

背景

- HPCシステムの複雑化への対応
  - 並列性の増大
    - コア数とノード数
  - メモリ階層数の増大
  - 電力制約

少数のコアをOS専用としても，そのオーバヘッドは無視できる（1/32コアで3パーセント）

スケーラブルで安定した性能の提供と新ハードウェアへの迅速な対応がカギ

- アプリケーションの複雑化
  - 新しいプログラミングモデルの導入
    - 例：In-situデータアナリティクス、ワークフロー
  - 周辺ソフトの複雑化

Linux API で開発されることが多いため、Linux との ABI 互換性が重要

既存の膨大なツールチェインがそのまま使えることが重要

これらの要件を同時に満たせるか？


OUTSOURCING
IN-HOUSE SOLUTION

McKernel のアーキテクチャ

1. Interface for Heterogeneous Kernels (IHK): 複数の異種OSを持つためのフレームワーク
   - ノード資源のパーティショニング
   - LWKの管理（例：カーネルの起動、停止)
   - LWKとLinuxの間の通信機構（Inter-kernel communication, IKC)の提供
2. McKernel: スクラッチから開発されたHPC向けLWK
   - ノイズレス
   - 性能クリティカルなシステムコールのみMcKernelで動作、他はLinuxにオフロード

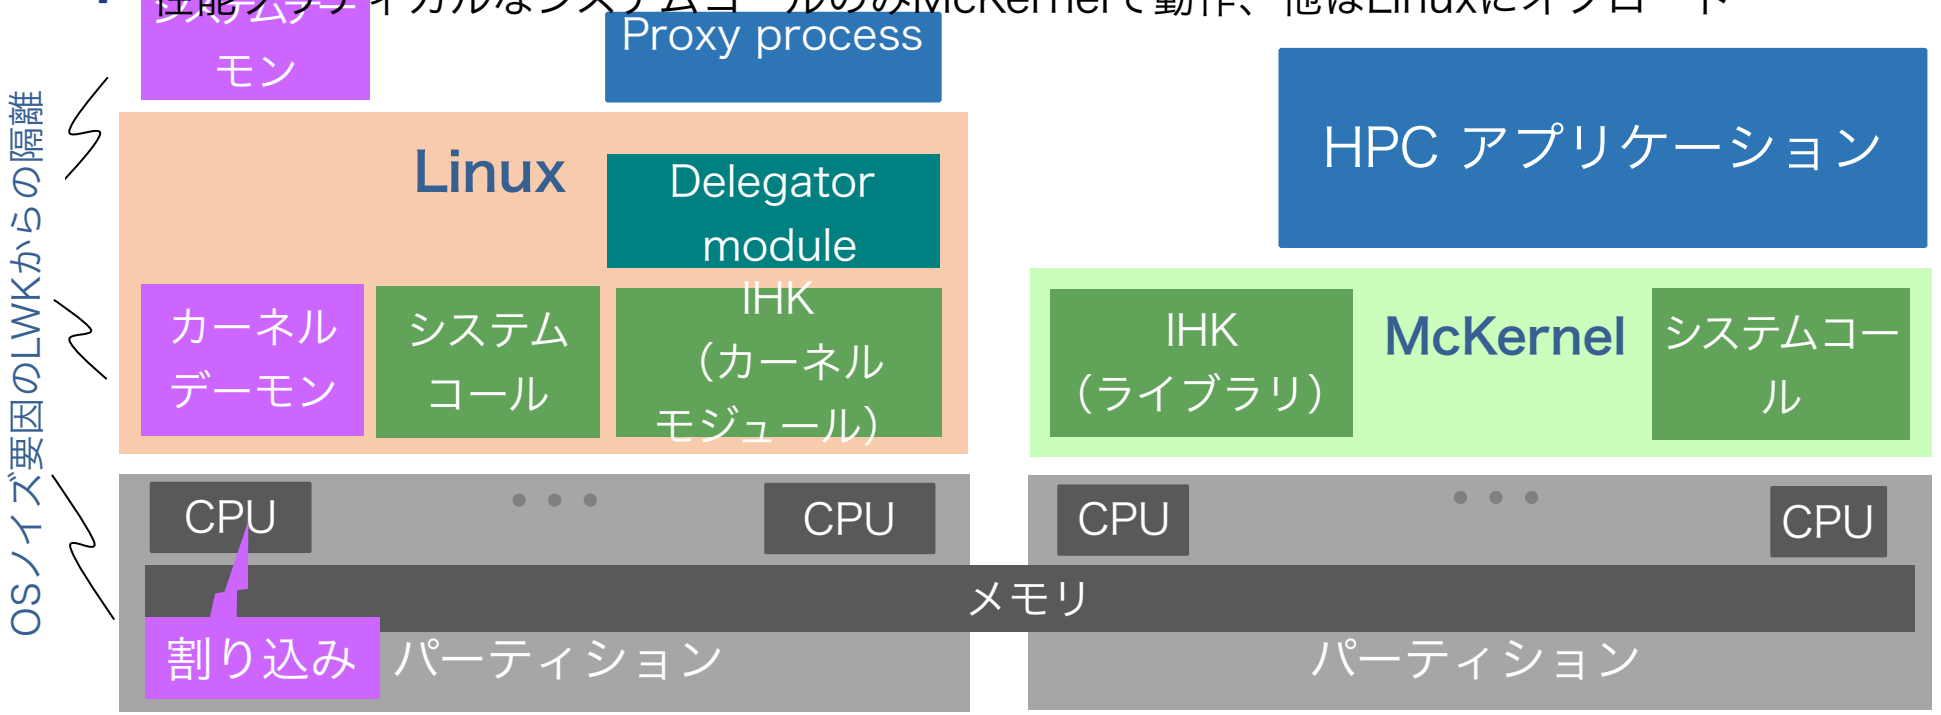

CCS-QCD (Hiroshima University)

- **Lattice quantum chromodynamics code – weak scaling**
- **Up to 38% improvement**

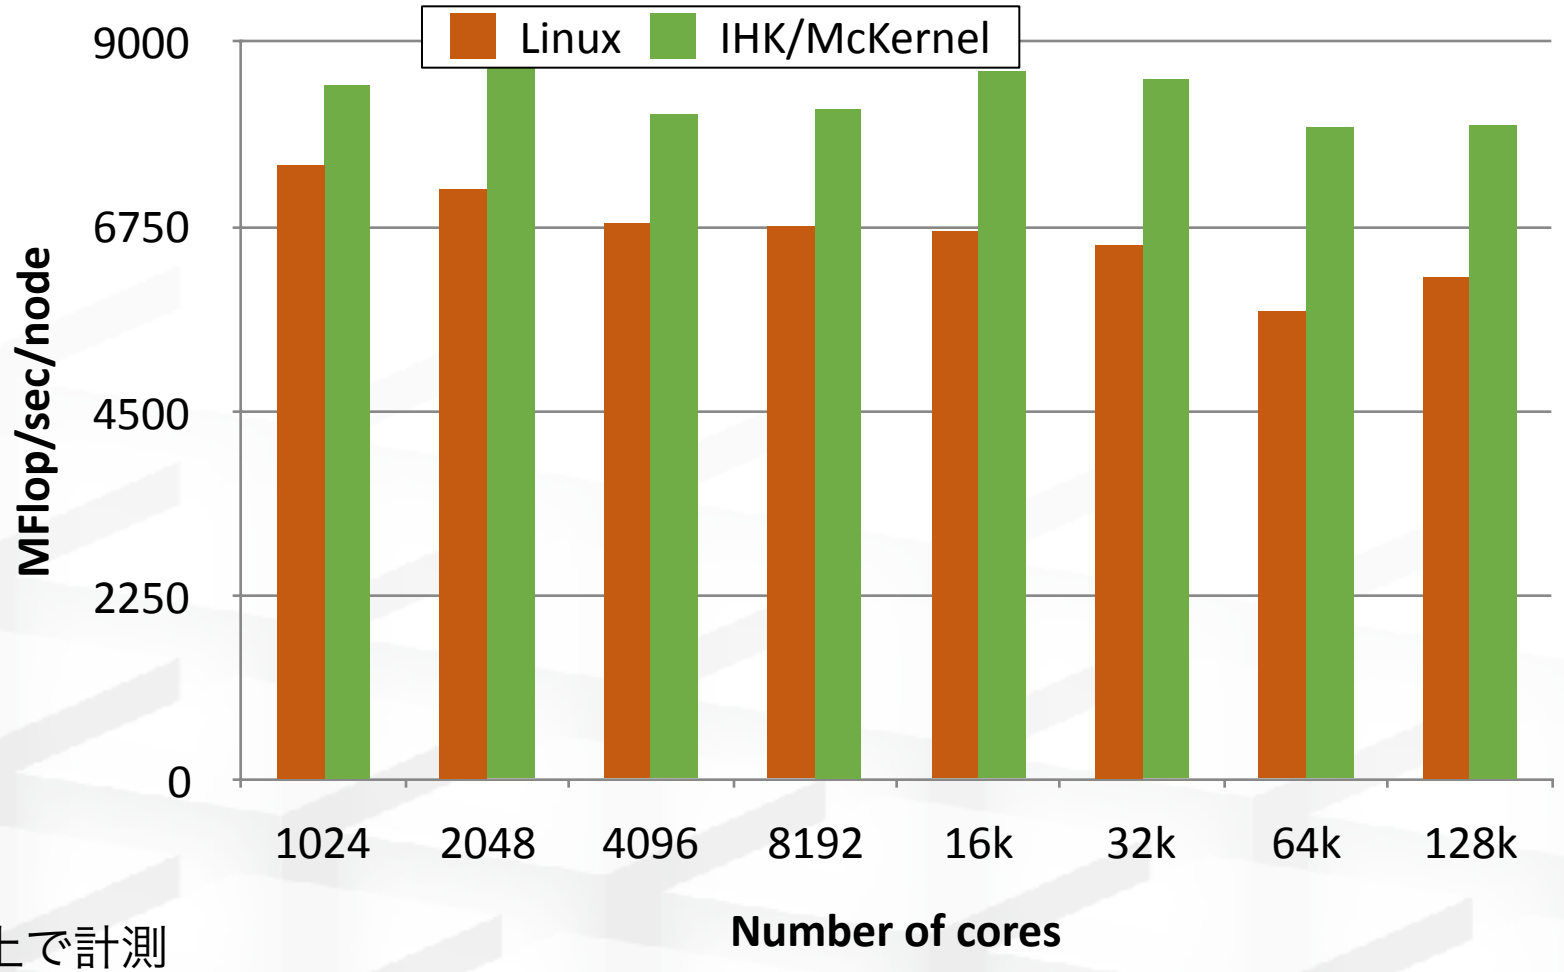

OFP上で計測

miniFE (CORAL benchmark suite)

- Conjugate gradient - strong scaling
- Up to 3.5X improvement (Linux falls over..)

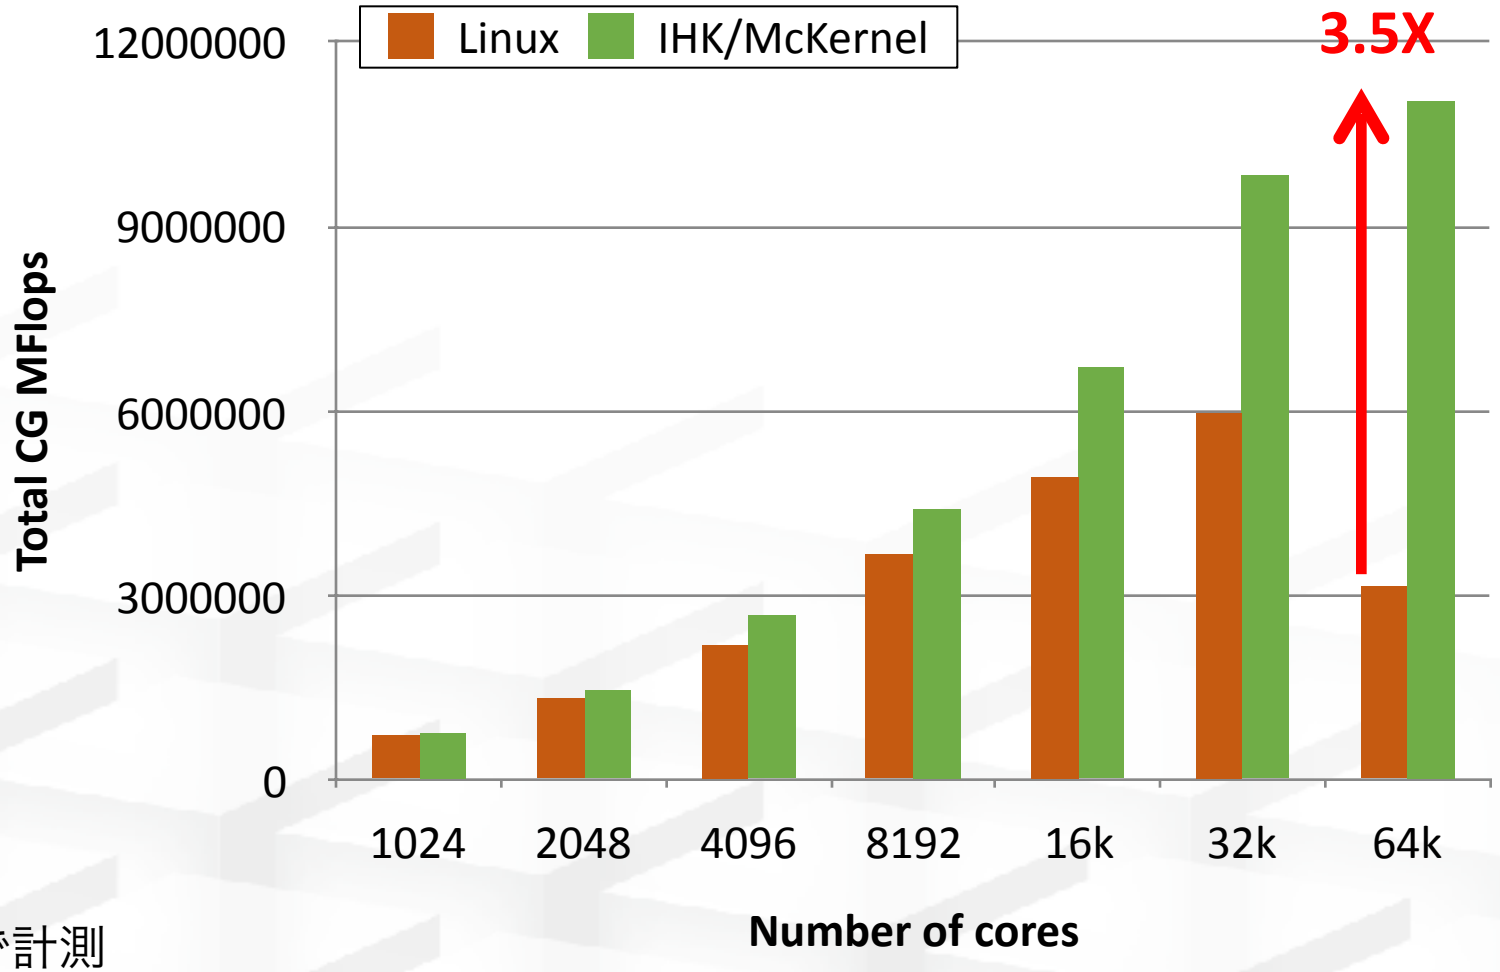

OFP上で計測

Single node: McKernel outperforms Linux across the board → multi-node Lammps suffers from network offloading..

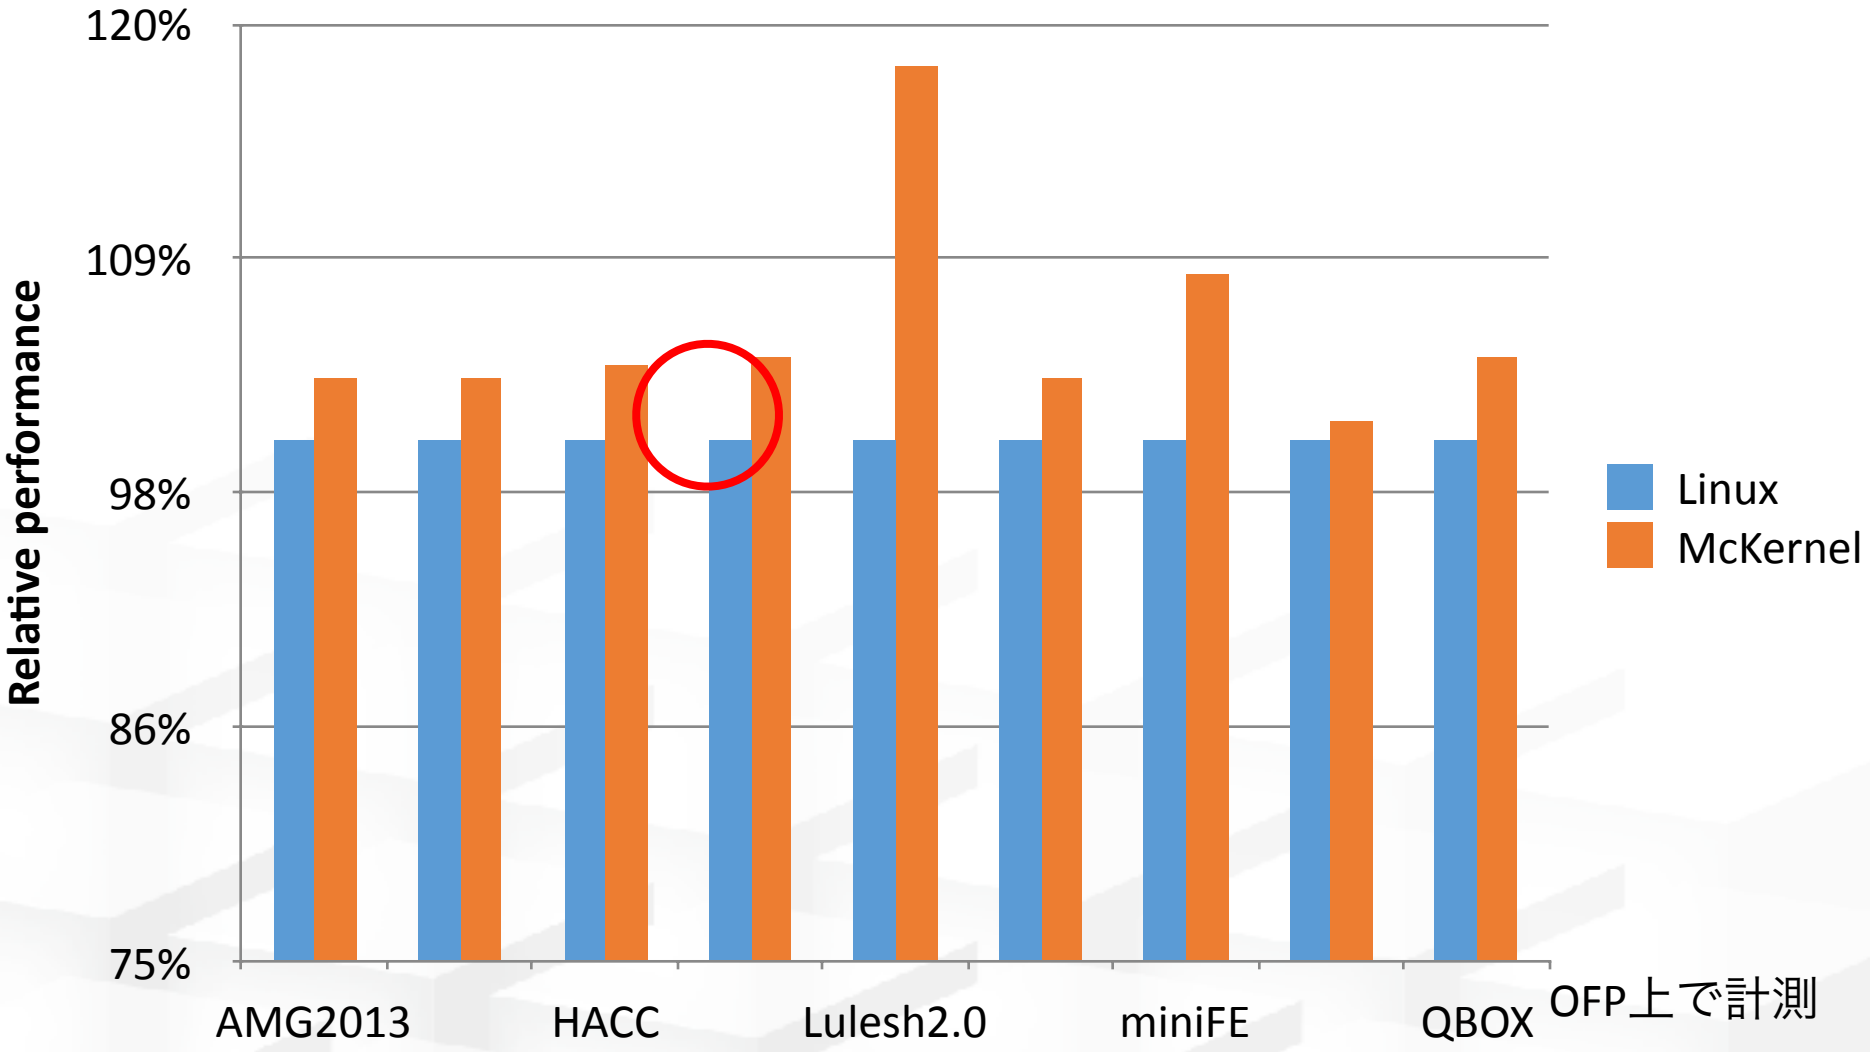

- lammps, HACC, QBOX ~4% better, as opposed to being slower than Linux on 8 nodes
- OmniPath offload overhead??

IHK/McKernel - まとめ

- **Xeon Phi 上でも動作**
  - Knights Landing (KNL)　　最新メニーコアCPU
- **Linux+IHK/McKernel**
  - LinuxコアでMapReduce，IHK/McKernelコアで並列アプリという動作でも，Linux だけよりも性能独立性が高い
  - Linuxよりはるかに単純なので，変更，機能追加が容易
    - IHK/McKernel：約 8 万行
    - Linux：2100万行！！（http://news.mynavi.jp/news/2016/04/11/130/）
- **より高いLinuxコンパチビリティ**
  - Procfs および numa 機能の実装など
- **実用性**
  - Linux を reboot せずに IHK/McKernel を boot できる
- **実戦配備**
  - Oakforest-PACS（東大・筑波大）で採用
  - ポスト京コンピュータでも採用される予定

Process in Process (PIP)

背景

- **メニーコアの台頭**
  - これまでのノード内並列モデルのままで良いのか？
  - マルチプロセス（MPI）、マルチスレッド（OpenMP）

		Address Space	
		Isolated	**Shared**
Variables	**Privatized**	**Multi-Process (MPI)**	***3rd Exec. Model***
	Shared	??	**Multi-Thread (OpenMP)**

壁と線

遮蔽のための壁

区切りの線

PiPの動作モデル

- Root Process
  - 通常のプロセス
  - PiP task を spawn 可能
- PiP task
  - Root から生成
  - Root と同じ仮想アドレス空間を共有

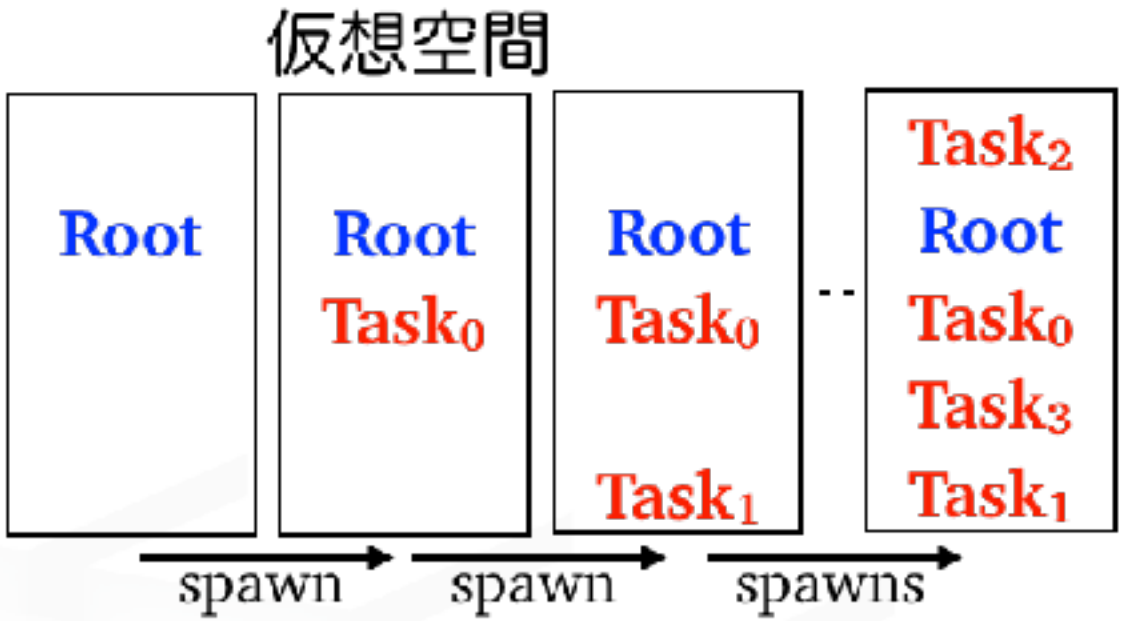

PiP は可搬性が高い

- 完全にユーザレベルのライブラリ
  - これまでの実装は、特殊なOSカーネルや専用のコンパイラが必要

Table 2: Experimental platform hardware information

Name	CPU	# Cores	Clock	Memory	Network
Wallaby	Xeon E5-2650 v2	8×2(×2)	2.6GHz	64 GiB	ConnectX-3
OFP†	Xeon Phi 7250	68(×4)	1.4GHz	96(+16) GiB	Omni-Path
K [44]	SPARC64 VIIIfx	8	2.0GHz	16 GiB	Tofu

Table 3: Experimental platform software information

Name	OS	Glibc	PiP Exec. Mode(s)
Wallaby	Linux (CentOS 7.3)	w/ patch	process and thread
Wallaby	McKernel+CentOS 7.3	w/ patch	thread only
OFP†	Linux (CentOS 7.2)	w/ patch	process and thread
K	XTCOS	w/o patch	process and thread

SNAPでの評価

- (MPI + OpenMP) ⇨ (MPI + PiP)

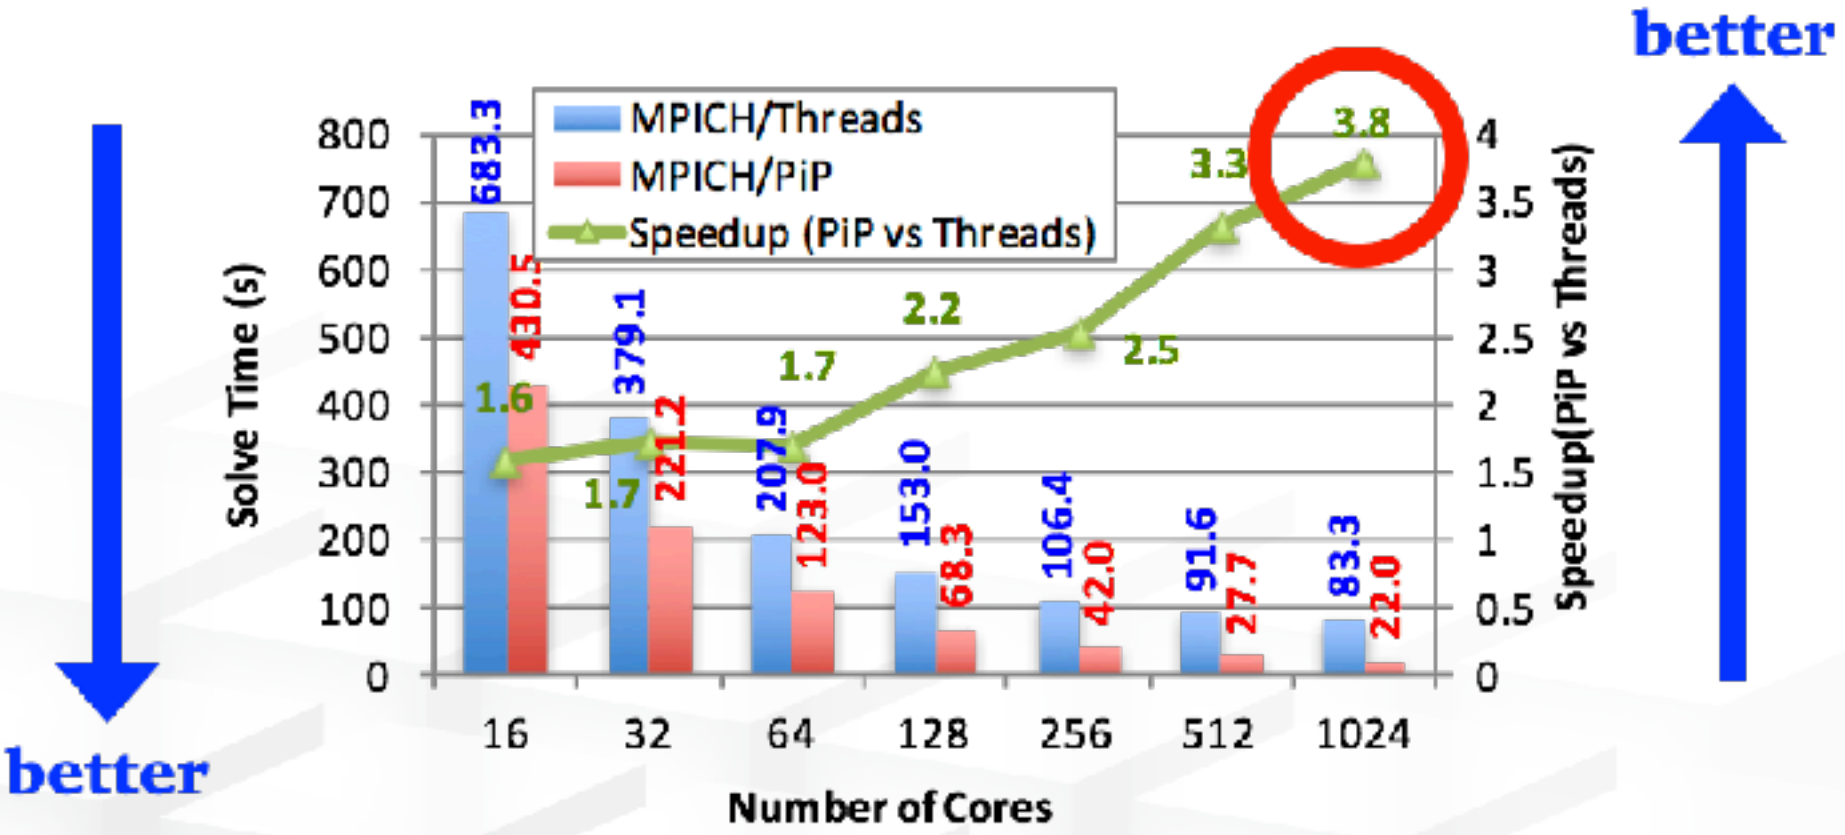

PiP V.S. threads in hybrid MPI+X SNAP
strong scaling on OFP (1-16 nodes, flat mode).

HPDC'18 で最優秀論文賞

PiP – まとめ

- **従来の２つのノード内並列実行方式、プロセス並列とスレッド並列のいいとこ取り**
- **これまでに提案された方式と異なり、ユーザレベルで実装される**
- **PiP により、以下の利点が期待される**
  - より高速なノード内通信
  - より低メモリ消費な並列実行環境

Github

https://github.com/RIKEN-SysSoft